

التنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى والصغرى في مدينة بغداد بأستخدام الشبكة العصبية المتعددة الطبقات

أ.م.د. بثينة عبد الجادر عبد العزيز

ALJaderb@yahoo.com

الجامعة المستنصرية - كلية الادارة والاقتصاد - قسم الاحصاء

أ.م. خولة حسين الوكيل

Khawlaalwakel@yahoo.com

الجامعة المستنصرية - كلية الادارة والاقتصاد - قسم الاحصاء

المستخلص:

يهدف البحث الى التنبؤ بالمعدلات الشهرية لدرجات الحرارة العظمى والصغرى لمحطة بغداد الانوائية بأستخدام الشبكة العصبية المتعددة الطبقات وقد تعامل البحث مع مشكلتين رئيسيتين في تحديد هيكلية الشبكة وهما تحديد عدد عقد الادخال، وتحديد العقد المخفية في الطبقة، ولقد اوضحت النتائج المستخرجة اهمية وكفاءة الشبكة من خلال الاختيار المناسب لعدد عقد الادخال وعدد العقد المخفية في الطبقة بأستخدام المقاييس الاحصائية AIC, BIC, AICC. وقد تم تقدير المعدلات الشهرية لدرجات الحرارة العظمى والصغرى لسنة 2013 بأستخدام النماذج المختارة ومقارنتها بالقيم الحقيقية المقاسة في محطة بغداد وبالاتتماد على المقاييس MSE, MDE, PMC ومن ثم تم اختيار النموذج الافضل لحساب التنبؤات المستقبلية لهذه الدرجات لسنة 2014.

الكلمات الرئيسية: الشبكات العصبية متعددة الطبقات، خوارزمية الانتشار الخلفي، طريقة تحديد الصلات اليا، معلومات اكيبي، التنبؤ.

1. المقدمة

تعد الحرارة من اهم عناصر المناخ، لانها تؤثر مباشرة على نشاط الانسان وحياته وغذائه، كما ان لها تأثير على بقية الاحياء على سطح الارض وينسحب هذا التأثير بشكل اكثر وضوحاً في النشاط الزراعي للانسان وعلى توزيع المساحات المزروعة للمحاصيل وعلى كمية المنتج السنوي منها اضافة الى تأثيرها على الانتاج الصناعي سواء كان في العمليات الصناعية المباشرة والجهد الانساني المبذول او في المواد الخام الصناعية الداخلة مباشرة في الصناعة مثلاً المحاصيل الغذائية وغيرها.

كذلك فإن التغيرات في درجة الحرارة لها التأثير الاكبر على عناصر المناخ الاخرى اذ ان تغير قيم درجات الحرارة يقود الى تغيرات في قيم بقية العناصر المناخية

لذا فإن التنبؤ بدرجات الحرارة شغلت اذهان الباحثين في الميترولوجيا، المناخ، البيئة ومختلف العلوم الاخرى لما تتعرض له الارض حالياً من تغيرات واضحة في درجات الحرارة وفق مايعرف بظاهرة الاحتباس (الاحترار) العالمي Global Warming والذي اشارت اليه معظم ادبيات المناخ والارصاد الجوي والبيئة وكل الهيئات المعنية بالمناخ حتى اصبح التغير المناخي مطروحاً بقوة على طاولة البحث العلمي.

لذا يصب هذا البحث في اولويات الاهتمام العالمي بهذه المشكلة والاهتمام المحلي اذ يساعد في معرفة اتجاه الحرارة المقبلة في العراق للاستعداد لها على مستوى التنمية المستدامة في جميع القطاعات والتكيف لها ما أمكن.

توجد اساليب احصائية كثيرة تستخدم لحساب التنبؤات المستقبلية لظاهرة معينة منها التمهيد الاسي - نماذج بوكس جنكز اضافة الى نموذج الخلية العصبية الصناعية والتي تمثل اقوى تقنيات الذكاء الاصطناعي Artificial Intelligence. وتعتبر الشبكة العصبية الصناعية محاكاة متواضعة بفعالها وشكلها ومضمونها للشبكة العصبية الحيوية الموجودة في الدماغ البشري الذي تتألف من الخلايا العصبية الحيوية المتصلة مع بعضها البعض بوصلات عصبية.

وشهدت السنوات القليلة الماضية توسعاً ملحوظاً في تطبيقات الشبكات العصبية منها اكتشاف المتفجرات المخبأة في حقائب السفر ، التحكم بسير العمليات الانتاجية، التنقيب عن النفط والتنبؤ باحوال اسواق الاسهم والمستندات المالية والتنبؤ بأحوال عناصر المناخ كدرجات الحرارة العظمى والصغرى والامطار والضغط الجوي وغيرها. اذ اثبتت نماذج الشبكات العصبية قدرتها على التنبؤ مقارنة مع الاساليب الاحصائية [7] او يمكن تطبيقها بدون النظر الى فرضية معينة في طبيعة المتغيرات وعلاقتها ببعضها البعض لذا فإن استخدامها يعد اداة فعالة ووسيلة مضمونة للوصول الى تنبؤات القيم المستقبلية لظاهرة ما.

درس عدد من الباحثين مسألة التنبؤ بدرجات الحرارة العظمى والصغرى منهم من استخدم اسلوب الشبكات العصبية كأنموذج انحدار غير خطي متعدد Multiple Non Linear Regression Model نذكر منهم Hayati و Mohebi [9] ، S.S.D.e [13] ، Baboo و Sheref [14] ، Hayati و Mohebi [9] ، S.S.D.e [13] ، وذلك بالاعتماد على عناصر المناخ الاخرى المتمثلة (بالحرارة الجافة ، الحرارة الرطبة ، سرعة الرياح ، الرطوبة النسبية ، الضغط الجوي ، السطوع الشمسي ، الاشعاع) باعتبارها متغيرات مفسرة.

والاخر استخدم اسلوب الشبكات العصبية كأنموذج انحدار ذاتي غير خطي Non Linear Auto Regressive Model اذ تمثل كل من درجات الحرارة العظمى والصغرى سلسلة زمنية نذكر منهم Ricardo و Palutiko [11]، و-Singh

[4] Kaur و Mahbouben وآخرون [8]، و Abhisneu وآخرون [3]، و [10] و GANJU, Joshi، و Govind وآخرون [5]، و Kihoro وآخرون [7].

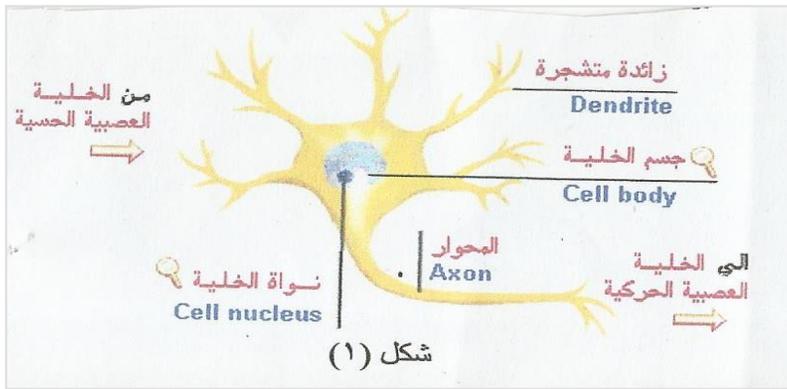
2. هدف البحث

يهدف البحث الى حساب التنبؤات المستقبلية للمعدلات الشهرية لدرجات الحرارة العظمى والصغرى لمدينة بغداد بأستخدام أنموذج الشبكات العصبية المتعددة الطبقات (Multi – Layer Net Works).

ولتحقيق هذا الهدف قسم البحث الى جانبين الاول يمثل الجانب النظري الخاص بالاسس النظرية للشبكات العصبية الصناعية والثاني يتناول الجانب التطبيقي حيث يتم التطبيق لبيانات واقعية تمثل المعدلات الشهرية لدرجات الحرارة العظمى والصغرى لمدينة بغداد من الفترة 1980-2013 بعدها جملة من الاستنتاجات والتوصيات.

3. الخلية العصبية الحيوية والخلية العصبية الصناعية [1] Biological neural cell and Artificial neural cell

يتكون الدماغ البشري من خلايا عصبية وكل خلية عصبية تتألف من ثلاثة اقسام هي نهايات عصبية (زوائد شجرية Dendrites) ونواة Cell nucleus ومحور عصبي (غمد Axon) حيث تتلقى الاشارة من الخلايا الاخرى وتنتقل تلك الاشارة عبر نقاط التشابك العصبي Synapses بواسطة معالجة كيميائية والتي بدورها تعدل من قيمة الاشارة ثم تجمع النواة الاشارة القادمة ثم تخرج الاشارة عبر الغمد فالنهايات العصبية كما في الشكل (1)



الشكل (1) مكونات الخلية العصبية الحيوية [1]

اما الخلية العصبية الصناعية فقد صممت لتحاكي خصائص الخلية العصبية الحيوية حيث استوحى العلماء الخطوط العريضة لبنية الشبكات العصبية من الدماغ البشري، وهي بالمثل تحتوي على وحدات معالجة بسيطة تقابل النواة ووصلات ادخال تقابل الزوائد الشجرية ووصلات اخراج تقابل المحاور العصبية وتتصل هذه الوحدات ببعضها البعض عن طريق نقاط الاتصال تقابل التشابك العصبي ويخصص لكل نقطة اتصال وزن Weight.

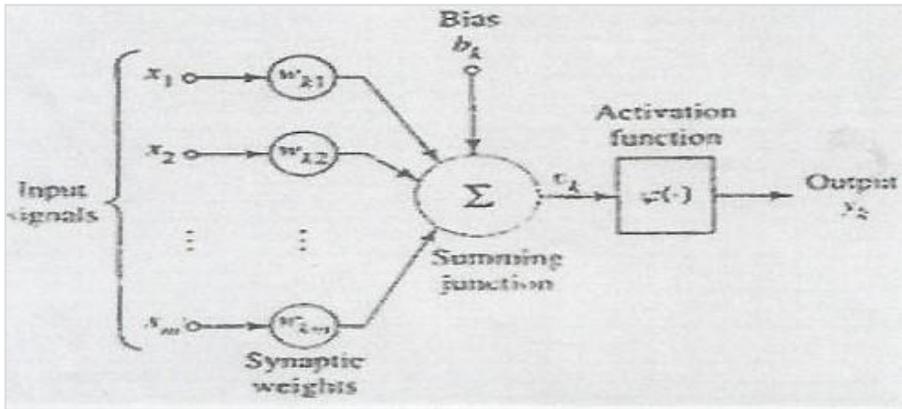
تستقبل الخلية العصبية الصناعية عناصر الادخال (المعلومات) ويتم ضرب كل عنصر بالوزن المرافق له W_i وهذا يقابل المعالجة الكيميائية في المشابك العصبية الحيوية وبعد ان يتم ضرب جميع عناصر الادخال بالاوزان المرافقة لها يتم جمعها في خلية الجمع ويكون الناتج بالشكل الاتي

$$Net = X_1 W_1 + X_2 W_2 + \dots + X_n W_n \quad \dots\dots(1)$$

يتم ادخال ومعالجة Net في تابع التنشيط لينتج بذلك ناتج الخلية العصبية Output اذ ان

$$Output = R (Net)$$

حيث ان R دالة تنشيط قد تكون خطية او غير خطية كما في الشكل(2)



شكل (2) مكونات الخلية العصبية الصناعية [1]

4. دالة التنشيط [6] Activation Function

تعرف بدالة التحويل Transfer Function لانها تقوم بتحويل المدخلات عبر تفاعلها مع الاوزان من صيغة الى اخرى وتكون منها الخطية وغير الخطية ومنها الدوال الشائعة الاستخدام هي:

4.1 الدالة اللوجستية Log-Sigmoid Function

تعد هذه الدالة الاكثر استخداماً عند عقد الطبقة المخفية للشبكة التي مدخلاتها ذات قيم حقيقية بين $(-\infty, \infty)$ اما مخرجاتها لكل عقدة تكون بين $(0,1)$ والصيغة الرياضية لها هي :

$$f(x) = \frac{1}{1 + \exp(-x)} \dots\dots\dots(2)$$

ومشتقتها

$$f'(x) = f(x) [1 - f(x)] \dots\dots\dots(3)$$

4.2 الدالة اللوجستية ثنائية القطب (دالة القطع الزائد المماس) Hyper Bolic Tangent Function

وتكتب بالشكل الاتي :

$$f(x) = \tanh(x) = \frac{1 - \exp(-2x)}{1 + \exp(-2x)} \dots\dots\dots(4)$$

ومشتقتها هي

$$f'(x) = \text{sech}^2(x) = 1 - \tanh^2(x) = (1 - f^2(x)) \dots\dots\dots(5)$$

4.3 الدالة الخطية The Linear Function

تستخدم هذه الدالة عند طبقة الاخراج في حالة التنبؤ وصيغتها

$$Output = R (Net) \dots\dots(6)$$

5. تعديل البيانات Data Normalization

هي عملية تهيئة البيانات قبل معالجتها (Pre –Processing) لاستخدامها في عملية تدريب الشبكة العصبية لذلك فإن مجال هذه البيانات لابد ان يكون ضمن نطاق دالة التنشيط ، توجد عدة طرق للتهيئة هي :-

5.1 الصيغة المبسطة Simple Formula

5.2 الصيغة الطبيعية Normalized Formula

تستخدم هذه الصيغة عندما تكون دالة التنشيط في عقدة الاخراج هي الدالة اللوجستية.

5.3 الصيغة المعيارية Standardized Formula

تستخدم هذه الصيغة عندما تكون دالة التنشيط في عقدة الاخراج هي الدالة الخطية.

5.4 الصيغة الطبيعية المعدلة Adjusted Normalized Formula

تستخدم هذه الصيغة عندما تكون دالة التنشيط من النوع اللوجستية الثنائية القطب (القطع الزائد المماس).

6. الشبكات العصبية المتعددة الطبقات [4] Multi – Layer Networks

تتكون هذه الشبكات من طبقة واحدة او اكثر من الطبقات المخفية (Hidden Layer) التي بدورها تحتوي على عدد من العقد المخفية (Hidden Nodes) وهذه الشبكات تتألف من ثلاث مستويات

6.1 مستوى المدخلات Inputs Level

يمثل المستوى الاول في الشبكة ويحتوي على عدد من العقد التي تمثل عدد المتغيرات المفسرة (المدخلات) ويتم فيه تلقي المعلومات المطلوب معالجتها ونود ان نشير عندما تكون وحدات الادخال متغيرات توضيحية فإن أنموذج الشبكات العصبية سيكون مشابه الى أنموذج الانحدار غير الخطي المتعدد وعندما تكون وحدات الادخال

تمثل ازاحات المتغير المعتمد (Lags) فأن أنموذج الشبكة سيكون مشابه الى أنموذج الانحدار الذاتي غير الخطي Non Linear Autoregressive Model.

6.2 المستوى المخفي Hidden Level

يمثل المستوى الثاني من الشبكة وهذا المستوى قد يكون طبقة واحدة مخفية او عدة طبقات والتي بدورها تحتوي على عدد من العقد المخفية ولكل عقدة وزن يربطها مع المستوى السابق (المدخلات) ووزن يربطها مع المستوى اللاحق (مستوى المخرجات) اذ يتم فيه معالجة المعلومات.

6.3 مستوى المخرجات Output Level

يمثل المستوى الاخير في الشبكة العصبية وهو عبارة عن مخرجات الشبكة حيث يتم اخراج نتائج المعالجة الى الوسط الخارجي.

7. عمل الشبكة العصبية [6] Neural network work

يمكن توضيح عمل الشبكة العصبية اذا كانت مكونة من طبقة مخفية واحدة وعدد عقد المدخلات اثنان هما Y_{t-12} , Y_{t-1} وعدد العقد (2) في الطبقة المخفية فأن

$$V_j = \sum W_{ij} Y_i \quad \dots\dots\dots(7)$$

وبأستخدام الدالة اللوجستية فأن

$$Z_j = 1 / (1 + \exp(-V_j)) \quad \dots\dots\dots(8)$$

فأن الناتج النهائي سيكون

$$\hat{Y}_t = \varphi_0 \left\{ W_{05} + \sum_{h=3}^4 W_{h5} \varphi_h \left(W_{oh} + \sum_{i=1}^2 W_{ih} Y_{t-ji} \right) \right\} \quad \dots\dots\dots(9)$$

اذ ان W_{oh} : تمثل الاوزان التي تربط بين الثابت (Baise) والعقد المخفية والتي هي W_{03} , W_{04} .

W_{05} : الاوزان التي تربط بين الثابت (Baise) والنتاج Output .

W_{ih} : الاوزان بين المدخلات Input والعقد المخفية .

W_{h5} : الاوزان بين العقد المخفية والنتاج Output.

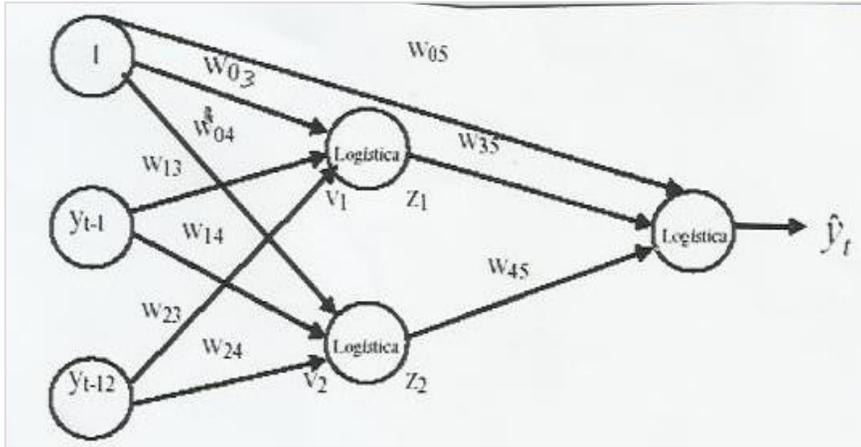
φ_0 : دالة التنشيط (التفعيل) في مستوى المخرجات وعادة ما تكون خطية.

φ_h : دالة التنشيط في المستوى المخفي وعادة ما تكون لوجستية

h : عدد العقد المخفية

I : عدد عقد الادخال

والشكل (3) يوضح ذلك



شكل (3): عمل الشبكة العصبية الصناعية اذا كانت مكونة من طبقة مخفية واحدة وعدد المدخلات (2) وعدد العقد في الطبقة المخفية (2)(6)

8. انواع الشبكات العصبية المتعددة الطبقات

8.1 الشبكات الامامية Feed Forward Networks

ان وحدات المعالجة في الشبكات الامامية يتم اتصالها بحيث تتدفق باتجاه واحد من عقد الادخال الى عقد الاخراج ومنها شبكة الانتشار الخلفي Back Propagation .

8.2 الشبكات الارجاعية (Recurrent Networks)

تحتوي هذه الشبكات على وصلات بالاتجاه الامامي والخلفي وتكون اما شبكات ارجاعية جزئية او شبكات ارجاعية تامة تمتلك وصلات بالاتجاه الامامي ووصلات بالاتجاه الخلفي وهذه الوحدات قابلة للتدريب ومن امثلتها شبكة Elman وشبكة Jordan.

9. خوارزمية الانتشار الخلفي Back Propagation Algorithm

تستخدم خوارزمية الانتشار الخلفي في عملية تدريب او تعلم الشبكات العصبية المتعددة الطبقات وان ظاهرة التدريب في الشبكة يعني تغير اوزان الاتصال (ضبطها) بين الخلايا المتصلة مع بعضها تبدأ الشبكة بعملية التدريب بادخال المعلومات الى الشبكة اذ تتعرف الشبكة العصبية على الخصائص والمزايا لهذه البيانات ثم تتدرب الشبكة على البيانات ونتيجة التدريب نحصل على الاوزان المثلى التي تعطي افضل تقدير لقيم المعيار وهي تمثل مخرجات الشبكة العصبية اذ يتم مقارنة هذه المخرجات المولدة بواسطة الشبكة مع مخرجات الهدف (المتغير المعتمد) لنحصل الخطأ (خطأ التدريب) Training Error الذي يمثل الفرق بين مخرجات الشبكة وقيم مخرجات الشبكة المرغوب فيها الذي يستخدم كأساس في عملية تعديل او تحديث الاوزان اذ ان هدف تدريب الشبكة على البيانات هو الحصول على اقل خطأ تدريب وبالتالي الحصول على الاوزان المثلى التي يتم اعتمادها في التنبؤ لبيانات جديدة لم تخضع للتعلم.

ان عملية تحديث الاوزان تتم وفق خوارزمية الانتشار الخلفي Back Propagation Algorithm التي تحدث اوزان الطبقة الاولى (طبقة مستوى المدخلات الى المستوى المخفي) عبر مرحلة الانتشار الامامي Feed Forward اما تحديث اوزان طبقة المستوى المخفي الى مستوى المخرجات فيكون عبر مرحلة الانتشار العكسي بالاعتماد على الخطأ والاوزان التي تم الحصول عليها عبر مرحلة الانتشار الامامي وان عملية التدريب باستخدام هذه الخوارزمية يحتاج الى تحديد القيم الاولى للاوزان وان هذه القيم اما تختار عشوائياً او يتم توليدها من توزيعات احصائية

او تؤخذ العينة $\frac{1}{\sqrt{Ni}}$ كقيمة اولية ولكل اوزان الشبكة اذ ان Ni : يمثل عدد عقد الادخال كذلك تحتاج عملية التدريب لمعرفة معدل التعلم او عامل الزخم اذ يستخدم في عملية تحديث الاوزان .

10. تحديد هيكلية الشبكة العصبية

لتحديد هيكلية الشبكة العصبية اذ يتطلب من مصمم الشبكة مهارة عالية وخبرة تجريبية في تحديد الخطوات الاتية:

10.1 تحديد عدد عقد الادخال [6] Determination of Inputs Nodes

إن المتغيرات في أنموذج السلسلة الزمنية تكون بدلالة المتغيرات المزاحة اي ان

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-p})$$

اذ ان (p) تمثل درجة الانحدار الذاتي اي انحدار Y_t على القيم السابقة له

ان تحديد هذه المتغيرات تمثل مشكلة كبيرة تواجه مصمم الشبكة العصبية وقد اقترحت عدة طرق منها :

1. الاعتماد على معاملات الارتباط الذاتي المعنوية للسلسلة الزمنية المستقرة.
2. الاعتماد على طريقة تجميع البيانات فإذا كانت شهرية فأن عدد عقد الادخال هي $P = 12$ واذ كانت فصلية فأن $P = 4$.
3. اقترح Kihoro وآخرون عام 2004 طريقة تحدد الصلات اليا [5] (Automatic Relevance Determination Method) لتحديد عدد المتغيرات المزاحة زمنياً التي لها تأثير على المتغير المعتمد Y_t وذلك بالاعتماد على حساب المقدار

$$Inf(L) = \sum_{h=1}^{N_h} W_{ih} W_{ho} \dots\dots\dots(11)$$

حيث ان $Inf(L)$ مختصر لكلمة Influence الذي يمثل التأثير الكلي على الناتج Output من قبل المتغير Y_{t-L} وعلى فرض ان:

$$r(L) = |inf(L)| \dots\dots\dots(12)$$

فإذا كانت قيمة $r(L)$ صغيرة فإنه يشير الى Y_{t-L} سوف لا يدخل في النموذج ويمكن تلخيص هذه القاعدة

1. تحديد عدد العقد المخفية.
2. نختار قيمة P التي نشك بأن يكون لها تأثير على القيمة المتنبأ بها.
3. ندرّب الشبكة بأستخدام كل الازاحات المختارة.
4. نحسب المقدار $\ln f$.
5. نختار قيمة k فإذا

$$P(Y(t-L) \in Y) = \left\{ \begin{array}{ll} 1 & \text{if } |r(L)| > k \\ 0 & \text{if } |r(L)| \leq k \end{array} \right. \quad L = 1, 2, \dots, P \dots \dots (3)$$

مع مراعاة الاخذ بنظر الاعتبار مجموع مربعات الاخطاء لمجموعة التدريب SSE_r ,

10.2 تحديد عدد الطبقات المخفية Determination of Hidden Layers

في اغلب تطبيقات التنبؤ بأستخدام الشبكات العصبية المتعددة الطبقات يفضل استخدام طبقة مخفية واحدة.

10.3 تحديد عدد العقد في الطبقة المخفية [6] Determination of Hidden Nodes

تواجه مصمم الشبكة العصبية مشكلة اخرى الا وهي تحديد عدد العقد في الطبقة المخفية فبعض الباحثين يختارها بعدد المتغيرات المزاحة زمنياً اي بعدد عقد الادخال في حين البعض الاخر يعتمد على مقياس $AIC, BIC, AICC$

$$AIC = N_t k \ln \hat{\sigma}^2 + 2 N_p \dots\dots\dots(14)$$

$$BIC = N_t \ln \hat{\sigma}^2 + N_p + N_p \ln (N) \dots\dots\dots(15)$$

$$AIC_C = AIC + \frac{2N_p (N_p + 1)}{N_t - N_p - 1} \dots\dots\dots(16)$$

اذ ان

N_p : عدد المعلمات في الخلية و N_t : حجم العينة لمجموعة التدريب و k :
 عدد عقد وحدة الاخراج

في حين ان الباحثين Kihoro وآخرون قد اقترحوا طريقة لتحديد عدد العقد المخفية
 بموجب الصيغة الآتية

$$N_h \leq \frac{(N_t - 1) * \varepsilon}{(N_I + 2)} \dots\dots\dots(17)$$

اذ ان

N_h : عدد العقد المخفية و N_I : عدد عقد المدخلات و ε : كمية موجبة فيها
 $\varepsilon \leq 0.125$

ان هذه الصيغة تعتمد على عدد عقد الادخال كلما قلت عددها زاد عدد العقد
 المخفية اذ ان العلاقة فيهما عكسية. كما يمكن تدريب الشبكة على عدد من العقد قد تكون
 $1,2,3,\dots,t$ ويختار العدد الذي يكون فيه مجموع مربعات الاخطاء اقل ما يمكن

10.4 تجزئة البيانات [6]

في الخلية العصبية الصناعية تجزأ البيانات الى:-

- ❖ مجموعة التدريب او التعلم Training Set : وهي المجموعة التي تستخدم لتقدير الاوزان وتدريب الشبكة على التنبؤ.
- ❖ مجموعة الاختبار Test Set : هي المجموعة التي تقوم بأختبار قابلية الشبكة العصبية على التنبؤ بعد عملية التدريب.
- ❖ مجموعة التقييم Validation Set : مهمتها مراقبة وتقويم اداء تدريب الشبكة.

لا توجد قاعدة عامة لتجزئة البيانات فأحياناً يكون 80% من البيانات لمجموعة التدريب و 20% لمجموعة الاختبار او 70% للتدريب و 30% للاختبار او 50% للتدريب و 50% للاختبار.

وفي النهاية يمكن القول ان اسلوب الخلية العصبية يماثل ويشابه النماذج الاحصائية التقليدية شائعة الاستخدام غير ان هناك اختلاف فيما يتعلق ببعض المصطلحات فالمتغيرات المفسرة تسمى مدخلات وقيم المتغير التابع تسمى قيم التدريب او قيم الهدف والقيم المنتبأ بها تسمى مخرجات الشبكة وتقدر المعلمات يسمى تدريب الاوزان او تحديثها.

10.5 تحديد عقد الاخراج Determination of Output Nodes

اتفق الباحثون على ان وجود عقدة اخراج واحدة تكفي لعملية التنبؤ بخطوة واحدة نحو الامام اما في حالة التنبؤ لعدة خطوات قادمة فأن عدد العقد يكون مساوياً الى عدد خطوات التنبؤ.

11. التنبؤ Forecasting [6]

ان الهدف الاساسي من استخدام أنموذج الشبكة العصبية هو حساب القيم المستقبلية للسلسلة الزمنية المدروسة. ففي حالة التنبؤ لخطوة واحدة (One-Step-ahead) يكون باستخدام المعادلة باستخدام المشاهدات الفعلية لكل المتغيرات المزاحة كمدخلات. اما في حالة التنبؤ لعدة خطوات ولتكن k (k-Step) يكون بطريقتين:

الاولى: يستخرج التنبؤ لخطوة واحدة ثم تدخل هذه القيمة للتنبؤ لخطوة ثانية وهكذا الى ان نحصل على k من التنبؤات وهي طريقة تكرارية مثل ما يحصل في تنبؤات بوكس جنكز وهنا نود ان نشير الى ان معمارية الشبكة لم تتغير وبوجود عقدة واحدة للنتائج كما موضح

$$\begin{aligned}\hat{Y}_{t+1} &= f(Y_t, Y_{t-1}, \dots, Y_{t-n}) \\ \hat{Y}_{t+2} &= f(\hat{Y}_{t+1}, Y_t, \dots, Y_{t-n+1}) \\ \hat{Y}_{t+3} &= f(\hat{Y}_{t+2}, \hat{Y}_{t+1}, \dots, Y_{t-n+2}) \quad \dots \quad (18) \\ \hat{Y}_{t+k} &= f(\hat{Y}_{t+k-1}, \hat{Y}_{t+k-2}, \dots, Y_{t-n+k-1})\end{aligned}$$

الثانية: باستخدام شبكة عصبية ذات k من عقد الاخراج تستخدم للتنبؤ الى تنبؤات متعددة مباشرة وباستخدام كافة المشاهدات السابقة وعليه فأن التنبؤات ل k من الخطوات

$$\begin{aligned}\hat{Y}_{t+1} &= f_1(Y_t, Y_{t-1}, \dots, Y_{t-n}) \\ \hat{Y}_{t+2} &= f_2(Y_t, Y_{t-1}, \dots, Y_{t-n}) \\ &\vdots \\ \hat{Y}_{t+k} &= f_k(Y_t, Y_{t-1}, \dots, Y_{t-n})\end{aligned} \quad \dots \quad (19)$$

حيث ان f_1, f_2, \dots, f_k هي دوال في الشبكة.

الجانب التطبيقي

في هذا الجانب سيتم التطبيق لبيانات واقعية تمثل المعدلات الشهرية لدرجات الحرارة العظمى والصغرى في الفترة 1980-2013 اذ يتم تشخيص أنموذج الشبكة العصبية المتعددة الطبقات ذات التغذية الامامية لكل من المعدلات الشهرية لدرجات الحرارة العظمى والصغرى.

وقد تم استخدام طبقة مخفية واحدة وبعدة اخراج واحدة واعتماد الصيغة المعيارية لتعديل البيانات وتجزئة هذه البيانات الى 70% مجموعة التدريب(التي تستخدم لتقدير الاوزان وتدريب الشبكة على التنبؤ) و 30% مجموعة الاختبار اما دوال التنشيط فقد تم استخدام الدالة غير الخطية (اللوجستية) معادلة رقم (2) عند الطبقة المخفية ودالة خطية عند عقدة الاخراج.

وكما ذكر في الجانب النظري من ان الباحث يواجه مشكلتين رئيسيتين هما تحديد عدد عقد الإدخال، تحديد عدد العقد المخفية.

اولاً: تحديد عقد الادخال Determination of Inputs Nods

لتحديد عدد المتغيرات المزاحة نعتمد على الطرق الاتية:

1. الطريقة المقترحة من الباحثين Kihoro واخرون اذ يتم بأخذ كل متغير مزاح مع Y_t وبيان مقدار تأثيره على Y_t من خلال حساب $|Inf(L)|$ بموجب المعادلة رقم (12) واستخراج مجموع مربعات خطأ التدريب وعليه سيكون الانموذج هو $NN(Y_{t-k}; 1) \quad k = 1, 2, \dots, 13$

جدول (1) يبين مقدار $|Inf|$ ومجموع مربعات خطأ التدريب للازاحات (1....13)

Lag	S.S.Et	Inf	S.S.Et	Inf
1	12.726	0.91823	39.263	0.978056
2	101.895	0.557	115.491	0.30499
3	132.812	0.026	133.536	0.013618
4	93.493	1.169	103.267	0.49708
5	37.603	1.384	44.895	1.118646
6	9.346	1.336	14.603	1.317366
7	45.048	1.4275	45.377	0.9765
8	102.842	1.309	109.563	0.62628
9	137.148	0.041	136.990	0.128797
10	103.677	0.624	39.156	1.082508
11	38.731	1.0438	8.730	1.190574
12	5.343	1.1362	41.178	1.155305
13	38.644	0.9713	34,620	0.99570
		(a)		(b)

م : من عمل الباحثين

a: للمعدلات الشهرية لدرجات الحرارة العظمى. b: للمعدلات الشهرية لدرجات الحرارة الصغرى.

ومن خلال ملاحظة قيم $|Inf|$ ومجموع مربعات خطأ التدريب الاول جدول رقم (1) (a) يمكن ان تحدد الازاحات المعنوية هي (1,6,12) اي ان نموذج الخلية العصبية هو $Y_t = f(Y_{t-1}, Y_{t-6}, Y_{t-12})$ لكلا السلسلتين.

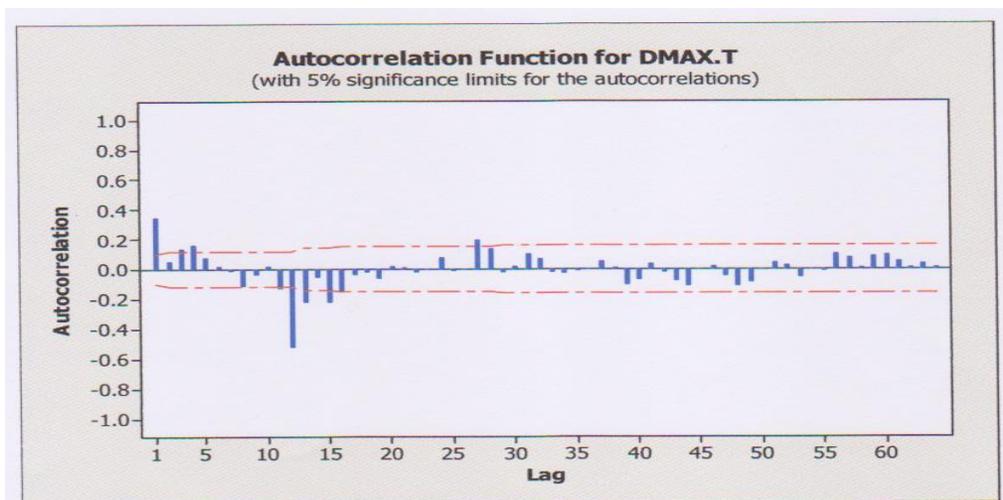
2. الاعتماد على معاملات الارتباط الذاتي المعنوية لسلسلة درجات الحرارة العظمى والصغرى المستقرة بعد ان اخذ لها الفرق الموسمي وجد ان معاملات الارتباط الذاتي لدرجات الحرارة العظمى معنوية فقط عند الازاحة الاولى والثانية عشرة كما في الجدول رقم (2) والشكل (4) كذلك وجد ان معاملات الارتباط الذاتي لدرجات الحرارة الصغرى معنوية عند الازاحة الاولى والازاحة الثانية عشر في الجدول (3) والشكل (5)

وعليه فان نموذج الخلية العصبية سيكون:- $Y_t = f(Y_{t-1}, Y_{t-12})$

اي ان عدد عقد الادخال هي اثنان والمتغيرات المزاحة هي Y_{t-1}, Y_{t-12}

جدول (2) معاملات الارتباط الذاتي لدرجات الحرارة العظمى بعد اخذ الفرق الموسمي

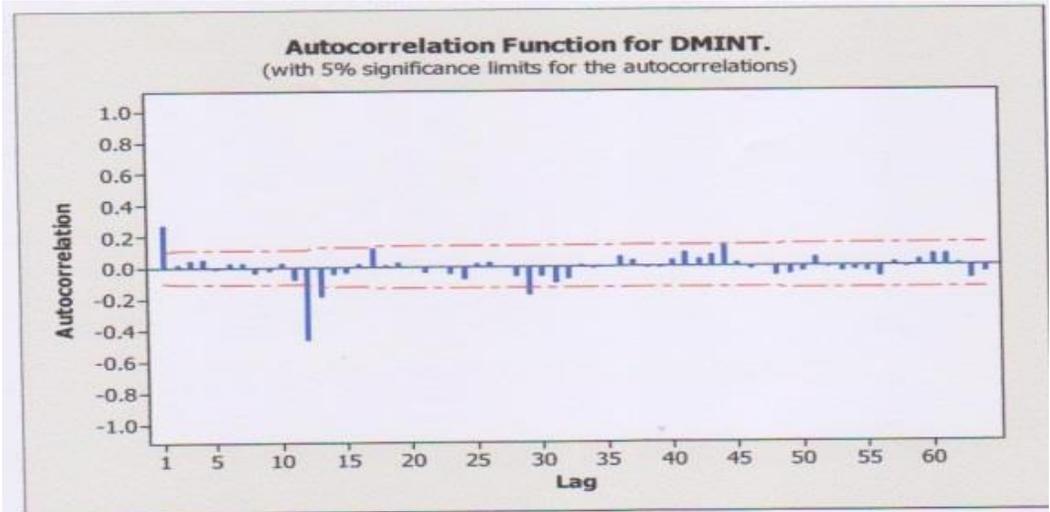
Lag	ACF	T	LBQ
1	0.344516	6.64	44.51
2	0.050331	0.87	45.46
3	0.131587	2.28	51.99
4	0.162965	2.78	62.03
5	0.075894	1.27	64.22
6	0.019931	0.33	64.37
7	-0.007723	-0.13	64.39
8	-0.111117	-1.85	69.11
9	-0.034955	-0.58	69.58
10	0.017150	0.28	69.69
11	-0.128415	-2.12	76.04
12	-0.519708	-8.46	180.43
13	-0.215196	-2.98	198.37
14	-0.051546	-0.70	199.41



شكل (4) دالة الارتباط الذاتي للمعدلات الشهرية لدرجات الحرارة العظمى بعد اخذ الفرق الموسمي

جدول (3) معاملات الارتباط الذاتي للمعدلات الشهرية لدرجات الحرارة الصغرى بعد اخذ الفرق الموسمي

Lag	ACF	T	LBQ
1	0.267651	5.24	27.72
2	0.016353	0.30	27.83
3	0.040319	0.74	28.46
4	0.051804	0.95	29.51
5	-0.012265	-0.22	29.57
6	0.029057	0.53	29.90
7	0.022826	0.42	30.10
8	-0.029385	-0.54	30.44
9	-0.018376	-0.33	30.58
10	0.026882	0.49	30.86
11	-0.078771	-1.43	33.33
12	-0.456379	-8.26	116.32
13	-0.185201	-2.88	130.02
14	-0.040557	-0.62	130.68



شكل (5) دالة الارتباط الذاتي للمعدلات الشهرية لدرجات الحرارة العظمى بعد اخذ الفرق الموسمي

3. ان بيانات السلسلة الزمنية المدروسة تمثل المعدلات الشهرية لدرجات الحرارة فأن المتغيرات المزاحة هي Y_{t-k} , $k=1,2,\dots,12$ اي ان نموذج الخلية العصبية يحوي على 12 عقدة ادخال والذي هو:-

$$Y_t = f(Y_{t-1}, Y_{t-2}, \dots, Y_{t-11}, Y_{t-12})$$

ثانياً : تحديد عدد العقد المخفية Determination of Hidden Nodes

1. ان عدد العقد المخفية تعتمد على عدد عقد الادخال ولهذا فأن أنموذج الخلية العصبية سيكون حسب عدد عقد الادخال كما في الجدول (4)

جدول (4) يمثل عدد العقد المخفية حسب عدد عقد الادخال المستخرجة ونموذج الخلية العصبية

الطريقة	عدد عقد الادخال	عدد العقد المخفية	النموذج
1	3	3	NN(1,6,12;3)
2	2	2	NN(1,12;2)
3	12	12	NN(1,2,...,12;12)

اذ ان الرمز $NN(j_1, j_2, \dots, j_k; h)$ الازاحة الزمنية h تمثل عدد العقد المخفية

2. استخدام الصيغة المقترحة من قبل الباحثين Kihoro واخرون بموجب المعادلة رقم (17) لكل طريقة من طرق تحديد عدد عقد الادخال فكانت النتائج كما في الجدول (5)

جدول (5) عدد العقد المخفية المستخرجة بموجب المعادلة 17 والنموذج الخاص

الطريقة	عدد عقد الادخال	عدد العقد المخفية	النموذج
1	3	7	NN(1,6,12; 7)
2	2	9	NN(1,12; 9)
3	12	3	NN(1,.....,12; 3)

نظراً لعدم تساوي الطريقتين في اختيار عدد العقد لذا سيتم اخذ عدد العقد (3-7) بالنسبة للنموذج الاول (2-9) بالنسبة للثاني و (3-12) بالنسبة للنموذج الثالث وحساب المقاييس الاحصائية AIC , AIC_C , BIC وكما في الجدول (6) .

جدول (6) المقاييس الاحصائية AIC , AIC_C , BIC t للنموذج الاول بعقد (3-7) لدرجات الحرارة العظمى

الانموذج	عدد المعالم	AIC	BIC	AIC_C
NN(1,6,12,3)	16	-1003.781	-981.0891	-1001.5605
NN(1,6,12,4)	21	-990.809	-961.0602	-986.94
NN(1,6,12,5)	26	-976.0674	-939.1026	-970.13
NN(1,6,12,6)	31	-1039.879	-995.5067	-1031.54
NN(1,6,12,7)	37	-1008.256	-956.8433	-996.7236

جدول (7) المقاييس الاحصائية AIC , AIC_C , BIC للنموذج الثاني بعقد (9-2)

لدرجات الحرارة العظمى

الانموذج	عدد المعالم	-1013.85051	-1001.05716	AIC_C
NN(1,12,2)	9	-1042.8119	-1024.2117	-1013.142339
NN(1,12,3)	13			-1041.39713
NN(1,12,4)	16	-983.44	-960.80187	-981.20232
NN(1,12,5)	20	-1004.4167	-975.8864	-1001.00207
NN(1,12,6)	24	-1029.235	-994.80614	-1024.3767
NN(1,12,7)	28	-996.629	-956.96304	-989.629
NN(1,12,8)	32	-1008.1065	-962.302916	-999.05104
NN(1,12,9)	36	-962.9830	-911.86463	-951.19539

جدول (8) المقاييس الاحصائية AIC , AIC_C , BIC للنموذج الثالث بعقد (12-3)

لدرجات الحرارة العظمى

الانموذج	عدد المعالم	AIC	BIC	AIC_C
NN(1,2,...,12;3)	43	-1110.0153	-1009.0557	-1039.7049
NN(1,2,...,12;4)	57	-1066.438	-985.4066	-1034.3409
NN(1,2,...,12;5)	71	-1132.252	-1029.284	-1083.5667
NN(1,2,...,12;6)	85	-1018.792	-898.378	-935.2500
NN(1,2,...,12;7)	99	-1037.5199	-895.814	-921.049
NN(1,2,...,12;8)	113	-972.1323	-810.936	-803.740
NN(1,2,...,12;9)	127	-913.584	-733.250	-830.433
NN(1,2,...,12;10)	141	-973.1091	-769.498	-678.66
NN(1,2,...,12;11)	155	-904.1562	-682.795	-472.3705
NN(1,2,...,12;12)	167	-895.2475	-651.4684	-358.238

م : من عمل الباحثين

ومن خلال ملاحظة الجداول (8,7,6) نجد ان اقل قيمةً للمقاييس الاحصائية كانت للنماذج:

1. النموذج NN(1,6,12;6) الذي يضم ثلاثة متغيرات مزاحة هي $(y_{t-12}, y_{t-6}, y_{t-1})$ وستة عقد مخفية.
2. لنموذج NN(1,12;3) الذي يضم متغيرين مزاحين هما (y_{t-12}, y_{t-1}) وثلاثة عقد مخفية.
3. 3- النموذج NN(1,...,12;5) الذي يضم اثني عشرة متغير مزاح هي $(y_{t-1}, y_{t-2}, \dots, y_{t-12})$ وبخمس عقد مخفية.

لذا سنستخدم هذه النماذج لحساب التقديرات للمعدلات الشهرية لدرجات الحرارة العظمى لسنة 2013 ومقارنتها مع القيم الحقيقية لتلك السنة كما في الجدول (12) ومقارنتها مع القيم الحقيقية.

ثم حساب المقاييس الاحصائية الثلاثة لسلسلة درجات الحرارة الصغرى كما في الجدول (9) و(10) و(11)

جدول (9) المقاييس الاحصائية AIC, AIC_C, BIC للنموذج الاول بعقد (3-7) لدرجات الحرارة الصغرى

الانموذج	عدد المعالم	AIC	BIC	AIC_C
NN(1,6,12;3)	16	-1032.51285	-1009.235	-1030.483
NN(1,6,12;4)	21	-939.167	-909.244	-935.380
NN(1,6,12;5)	26	-916.4366	-879.263	-911.217
NN(1,6,12;6)	31	-839.851	-796.1958	-830.994
NN(1,6,12;7)	36	-948.090019	-895.881	-937.216

م: من عمل الباحثين

جدول (10) المقاييس الاحصائية AIC , AIC_C , BIC للنموذج الثاني
 بعقد (9-2) لدرجات الحرارة الصغرى

الانموذج	عدد المعالم	AIC	BIC	AIC_C
NN(1,12;2)	9	-1014.056	-1000.949	-1013.404
NN(1,12;3)	13	-893.005	-874.5035	-891.555
NN(1,12;4)	16	-940.860	-917.80626	-938.760
NN(1,12;5)	20	-944.945	-916.0332	-937.604
NN(1,12;6)	24	-893.4184	-859.221	-888.439
NN(1,12;7)	28	-910.4151	-870.069	-903.840
NN(1,12;8)	32	-850.458	-805.179	-841.1502
NN(1,12;9)	36	-820.063	-772.790	-807.954

م : من عمل الباحثين

جدول (11) المقاييس الاحصائية AIC , AIC_C , BIC للنموذج الثالث بعقد (12-3)
 لدرجات الحرارة الصغرى

الانموذج	عدد المعالم	AIC	BIC	AIC_C
NN(1,2,...,12;3)	43	-968.258	-907.2008	-950.980
NN(1,2,...,12;4)	57	-997.186	-915.416	-966.289
NN(1,2,...,12;5)	71	-949.732	-847.878	-898.612
NN(1,2,...,12;6)	85	-801.892	-683.46455	-711.7455
NN(1,2,...,12;7)	99	-813.473	-674.394	-684.9015
NN(1,2,...,12;8)	113	-847.481	-685.375	-684.418
NN(1,2,...,12;9)	127	-826.376	-645.209	-592.477
NN(1,2,...,12;10)	141	-753.539	-553.093	-425.309
NN(1,2,...,12;11)	155	-763.347	-541.986	-331.5613
NN(1,2,...,12;12)	167	-819.878	-572.986	-337.020

م : من عمل الباحثين

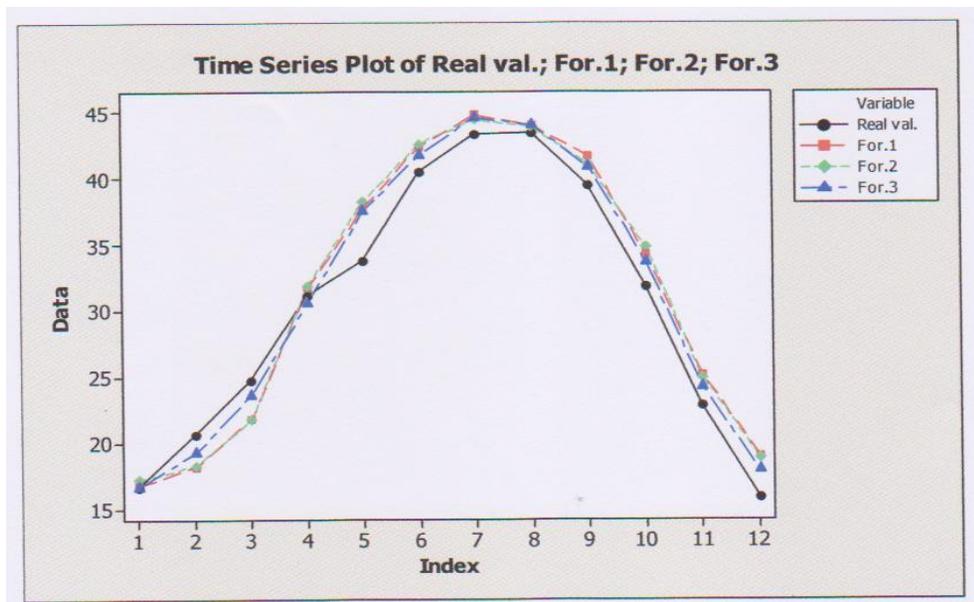
وعند ملاحظة الجداول (11,10,9) نجد ان اقل قيمة لهذه المقاييس كانت للنماذج الاتية:-

1. النموذج $NN(1,6,12;3)$ الذي يضم ثلاثة متغيرات مزاحة هي $(y_{t-12}, y_{t-6}, y_{t-1})$ وثلاثة عقد مخفية.
2. لنموذج $NN(1,2;2)$ الذي يضم متغيرين مزاحين هما (y_{t-12}, y_{t-1}) وعقدتين مخفيين.
3. لنموذج $NN(1, \dots, 12;4)$ الذي يضم اثني عشرة متغير مزاح هي $(y_{t-1}, y_{t-2}, \dots, y_{t-12})$ اربعة عقد مخفية، لذا سنستخدم كل من هذه النماذج لحساب التقديرات لسنة 2013 ومقارنتها مع القيم الحقيقية لسنة 2013 كما في جدول (14).

جدول (12) تقديرات المعدلات الشهرية لدرجات الحرارة العظمى لسنة 2013 مع القيم الحقيقية

الشهر	تقديرات النموذج الاول	تقديرات النموذج الثاني	تقديرات النموذج الثالث	القيم الحقيقية
1	16.74	17.22	16.66	16.7
2	18.2	18.31	19.31	20.7
3	21.79	21.80	23.63	24.8
4	31.71	31.82	30.58	31.1
5	37.69	38.25	37.51	33.8
6	42.36	42.59	41.72	40.5
7	44.79	44.45	44.61	43.3
8	43.96	43.85	44.03	43.4
9	41.65	41.00	40.81	39.5
10	34.21	34.76	33.62	31.8
11	25.10	24.93	24.18	22.8
12	18.99	18.89	17.88	15.9

وقد تم رسمها كما في الشكل (6)



شكل (6) رسم المعدلات الشهرية لدرجات الحرارة العظمى لسنة 2013 الفعلية مع التقديرات

وتم حساب المقاييس الاحصائية للنماذج الثلاثة لدرجات الحرارة العظمى وكانت كما هي في الجدول (13)

جدول (13) المقاييس الاحصائية (MSe وMED وPMC) للنماذج الثلاثة لدرجات الحرارة العظمى

The Model	MSe	MED	PMC
NN(1,6,12;6)	5.1731	0.65657	7.482618
NN(1,12;3)	5.4737	0.67538	7.5442578
NN(1,...,12;5)	2.6493	0.46986	4.9462579

م : من عمل الباحثين

اذ ان:

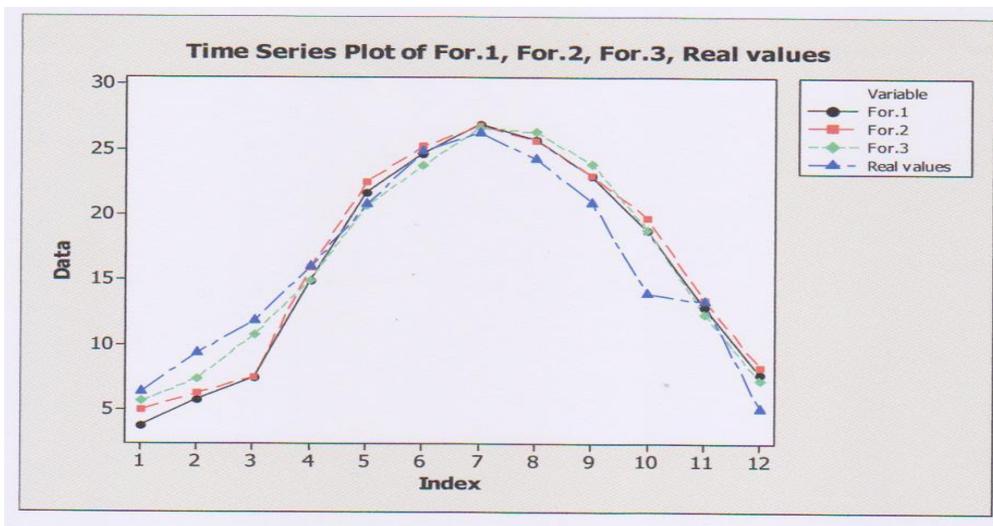
$$MSe = \frac{\sum e_i^2}{12}, MED = \sqrt{\sum e_i^2} / 12, PMC = \sum |e_i / y_{t+i}| * 100\% / 12$$

وبالنظر لكون النموذج NN(1,...,12;5) يمتلك اقل قيمة للمقاييس الثلاثة لذا سيستخدم هذا النموذج لحساب التنبؤات لدرجات الحرارة العظمى لسنة 2014 كما في جدول(16). كذلك تم حساب التقديرات لدرجات الحرارة الصغرى لسنة 2013 باستخدام النماذج الثلاثة ومقارنتها بالقيم الحقيق كما في جدول 14.

جدول (14) التقديرات المعدلات الشهرية لدرجات الحرارة الصغرى لسنة 2013 مع القيم الحقيقية

القيم الفعلية	التقديرات النموذج الثالث	التقديرات النموذج الثاني	التقديرات النموذج الاول	الشهر
6.4	5.62	4.98	3.72	1
9.4	7.40	6.22	5.81	2
11.8	10.75	7.47	7.48	3
16.0	14.97	15.90	14.94	4
20.8	20.70	22.52	21.67	5
24.9	23.77	25.25	24.65	6
26.3	26.68	26.85	26.94	7
24.3	26.34	25.69	25.74	8
20.9	23.89	23.01	23.03	9
13.9	18.81	19.70	18.82	10
13.3	12.38	13.45	12.95	11
5.1	7.24	8.28	7.71	12

وقد تم رسمها كما في الشكل (7)



شكل (7) رسم المعدلات الشهرية لدرجات الحرارة الصغرى لسنة 2013 الفعلية مع التقديرات

وقد تم حساب المقاييس الاحصائية للنماذج الثلاث فكانت كما في الجدول (15)

جدول (15) المقاييس الاحصائية (MSE وMED وPMC) للنماذج الثلاثة لدرجات الحرارة الصغرى

The Model	MSe	MED	PMC
NN(1,6,12;3)	6.5476	0.7386	52.5164
NN(1,12;2)	7.0385	0.76571	18.00254
NN(1,2,...,12;4)	4.2365	0.59417	13.5138

وقد تم استخدام النموذج NN(1,2,...,12;4) لحساب التنبؤات المستقبلية لدرجات الحرارة الصغرى لمدينة بغداد لسنة 2014 لكونه يمتلك اقل قيمة للمقاييس الثلاثة كما في جدول (16).

جدول (16) التنبؤات الشهرية لدرجات الحرارة العظمى والصغرى لسنة 2014

الشهر	المعدلات الشهرية لدرجات الحرارة العظمى المتنبأ بها	المعدلات الشهرية لدرجات الحرارة الصغرى المتنبأ بها
1	16.08	5.35
2	18.24	7.32
3	23.51	11.62
4	29.34	16.06
5	36.31	21.78
6	41.65	23.96
7	44.54	25.82
8	43.52	24.03
9	39.16	21.36
10	31.91	15.86
11	22.49	11.19
12	16.68	5.50

الاستنتاجات

1. من خلال الدراسة التطبيقية توصل البحث الى جملة من الاستنتاجات استناداً الى النتائج المستخرجة من خلال استخدام المقاييس الاحصائية الاتية (AIC_c, AIC, BIC) لاختيار عدد العقد المخفية وقد كانت النماذج التي تمتلك اقل قيمة لهذه المقاييس هي $NN(1,12;3)$ و $NN(1,6,12;6)$ و $NN(1, \dots, 12;5)$ بالنسبة للمعدلات الشهرية لدرجات الحرارة العظمى اما نماذج المعدلات الشهرية لدرجات الحرارة الصغرى والتي لها اقل قيمة للمقاييس الثلاثة هي $NN(1,6,12;3)$ و $NN(1,12;2)$ و $NN(1, \dots, 12;4)$.

2. عند استخدام المقاييس الاحصائية $MED, MSe, MAPE$ لاختيار النموذج الافضل وجد ان الانموذج $NN(1, \dots, 12;5)$ كونه يمتلك القيمة الاقل لهذه المقاييس لذا تم استخدامه لحساب التنبؤات لدرجات الحرارة العظمى في مدينة بغداد لسنة 2014، اما بالنسبة لانموذج المعدلات الشهرية لدرجات الحرارة الصغرى والذي يمتلك اقل قيمة لهذه المقاييس فقد كان $NN(1, \dots, 12;4)$ لذا تم استخدامه لحساب التنبؤات لدرجات الحرارة الصغرى في مدينة بغداد لسنة 2014.

3. وبالاعتماد على الفقرة الثانية نجد ان نموذج الشبكة العصبية للمعدلات الشهرية لدرجات الحرارة العظمى والصغرى متساوي في عدد عقد الادخال الذي هو 12 في حين عدد العقد المخفية هي 4 و 5 على التوالي.

التوصيات

1. استناداً الى الاستنتاجات يمكن ان نقترح ما يلي
نقترح استخدام نموذج للشبكة العصبية $NN(1, \dots, 12; 5)$ للتنبؤ بدرجات الحرارة العظمى في بغداد والانموذج $NN(1, \dots, 12; 4)$ للتنبؤ بدرجات الحرارة الصغرى في بغداد من قبل الدوائر ذات العلاقة منها الهيئة العامة للانواء الجوية العراقية والرصد الزلزالي.
2. اجراء دراسة موسعة للتنبؤ بالمعدلات الشهرية واليومية لدرجات الحرارة العظمى والصغرى في المحطات العراقية الاخرى باستخدام الشبكة العصبية متعددة الطبقات.
3. اجراء دراسة للتنبؤ بالقيم المستقبلية لعناصر المناخ الاخرى (الامطار، الرطوبة النسبية، الضغط الجوي وغيرها)، باستخدام اسلوب الشبكة العصبية متعددة الطبقات.

المصادر

- [1] الحسينى قصى حبيب واحمد عبد الامير الساعدي "مقدمة في الشبكات العصبية" جامعة الامام جعفر الصادق 2011.
- [2] الهيئة العامة للانواء الجوية العراقية والرصد الزلزالي، وزارة النقل والمواصلات، بيانات درجات الحرارة العظمى والصغرى الشهرية للمدة (1980-2013)، قسم المناخ، بيانات غير منشورة.
- [3] Abhishek Agrawal, Vikas Kumar, Ashish Pandey Jmrankhan, "AN Application of Time Series Analysis For Weather Forecasting", Engineering Research and Applications vol. 2, mar-Apr 2012, PP.974-98
- [4] Amanpreet Kaur, Harpreet Singh, "Artificial Neural Networks in Forecasting Minimum Temperature", IUECT vol.2, ISSUE 3, Sept. 2011.
- [5] Govind Kumar Rahul, Madhu Khurana, A.K. Sinha, "Weather Forecasting using Soft Computing: Minimum Temperature, Maximum Temperature and Pressure", International Journal of

- Engineering Research and Development, vol. 7, Issue 11 July 2013 PP. 10-17.
- [6] Julian Faraway, Chris Chatfield, "Time Series Forecasting with neural networks: a comparative study using the airline data", Appl. Statist. 47, part 2, pp. 231-250, 1998.
- [7] Kihoro, J.M, Otieno, R.O. , Wafwa, "SEASONAL Time Series Forecasting ;A comparative Study of ARIMA and ANN models", African Journal of Science and Technology (AJST) science and Engineering series vol.5, No. 2, PP41-49 December 2004.
- [8] Mahbouben Afzali, Afsaneh Azali and Gholamreza Zahedi, "Ambient Air Temperature Forecasting using Artificial Neural Network Approach", International Conference on Environmental and Computer Science IPCBEE vol.19,2011.
- [9] Mohsen Hayati and Zahra Mohebi , "Temperature Forecasting Based on Neural Network Approach", World Applied Sciences Journal 2(6) , 613-620 ,2007.
- [10] PIYUSH JOSHi and A. GANJU, "Maximum and Minimum Temperature Prediction over Western Himalya using Artificial Neural Networks ", MAUSAM,63,2, 283-290 April 2012.
- [11] Ricardo ,M.T. and Palutikof J.P., "Simulation of daily temperatures for Climate change scenarios over Portugal A neural network approach" Climate Research 13,45-59,1999.
- [12] S. Santhash Baboo and Ikadar Shereef , "An Efficient Weather Forecasting Using Artificial Neural Network", International Journal of Environmental Science and Development vol.1, No.4, October 2010
- [13] S. S. De, "Artificial Neural Network Based Prediction of Maximum and Minimum Temperature in the Summer Monsoon Months over India", Applied Physics Research vol.1, No. 2, November 2009.

Forecasting of Maximum and Minimum Monthly Averages of Temperature in Baghdad City Using Multi-Layer Neural Network

Dr. Buthaina Abduljadir

ALJaderb@yahoo.com

Al-Mustanisirya University
College of Administration and Economics

Khawla Hussain Alwakeel

Khawlaalwakel@yahoo.com

Al-Mustanisirya University
College of Administration and Economics

Abstract: *The research aims to forecast the averages of maximum and minimum temperature averages for Baghdad synoptic station by using the multi-layered neural network. The research deals with two major problems , First , determining the number of input nodes , second , determining the hidden nodes in the layer . The results showed the importance and qualification of the network through the proper choosing for number of input nodes and number of hidden nodes in the layer, by using the statistical procedures AIC , BIC , and ALCC . Then the maximum and minimum temperature averages for Baghdad station has predicted for 2013 by using the previous statistical procedures and compared its results with the real measured data for the station , by using the MSE , MDE , and PMC statistical procedures . and then*

select the best model to forecast of temperatures averages for 2014 .

Keywords: Multi-Layer Networks, Back propagation Algorithm, Automatic Relevance Determation method, AIC, Forecasting